



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV TELEKOMUNIKACÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF TELECOMMUNICATIONS

METODY SEGMENTACE BIOMEDICINSKÝCH OBRAZOVÝCH SIGNÁLŮ

METHODS FOR BIOMEDICAL IMAGE SIGNAL SEGMENTATION

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. LUKÁŠ KRUMPHOLC

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. JIŘÍ PŘINOSIL

BRNO 2009



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav telekomunikací

Diplomová práce

magisterský navazující studijní obor
Telekomunikační a informační technika

Student: Bc. Lukáš Krumpholc

ID: 83578

Ročník: 2

Akademický rok: 2008/2009

NÁZEV TÉMATU:

Metody segmentace biomedicinských obrazových signálů

POKYNY PRO VYPRACOVÁNÍ:

Prostudujte metody číslicového zpracování obrazů jejich možnost využití při segmentaci biomedicinských obrazových signálů. Vybrané metody realizujte jako skripty v programovém prostředí Matlab a jejich vlastnosti ověřte na snímcích z magnetické rezonance a tomografu. Proveďte vyhodnocení výsledků těchto metod a stanovte možné oblasti jejich použití.

DOPORUČENÁ LITERATURA:

- [1] JAN, J. Medical Image Processing, Reconstruction and Restoration - Concepts and Methods. Boca Raton, FL, USA: CRC Press, Taylor and Francis Group, 2005. ISBN: 0-8247-5849-8.
[2] SEMMLOW, K. J. Biosignal and Biomedical Image Processing: MATLAB-Based Applications, CRC Press, 2004, ISBN: 0-8247-4803-4.

Termín zadání: 9.2.2009

Termín odevzdání: 26.5.2009

Vedoucí práce: Ing. Jiří Přinosil

prof. Ing. Kamil Vrba, CSc.
Předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

Abstrakt

Tato práce se zabývá metodami segmentace biomedicínských obrazových signálů. Popisuje, shrnuje a porovnává vybrané metody zpracování digitálního obrazu.

Jednou z uvedených metod je segmentace založená na parametrickém vyjádření. Za základní parametr si můžeme zvolit například jas a prahováním pak získáme výsledný binární obraz. Další popisovanou metodou je segmentace na základě hranové reprezentace, kterou můžeme rozdělit na detekci hran pomocí hranových detektorů nebo pomocí Houghovy transformace. U hranových detektorů se využívá k detekci hran první, nebo druhá derivace.

Následuje regionově orientovaná segmentace, kterou využíváme pro zašumělý obraz, i tuto kategorii můžeme rozdělit na tři části. Segmentaci dělením a slučováním oblastí, kdy je obraz rozdělen a vzniklé oblasti jsou testovány na stanovenou podmínku, pokud ji splňuje, oblasti se spojí a dále se už nedělí. Na segmentaci růstem oblastí, kdy jsou sousední pixely s podobnou intenzitou jasu k sobě seskupovány a vytváří tak segmentovanou oblast. Na segmentaci algoritmem rozvodí, která je založena na představě rozlévání vody na nerovnoměrném povrchu.

Poslední skupinou metod je segmentace pomocí pružných a aktivních kontur. Zde je popsán aktivní tvarový model, který vychází z možnosti deformovat modely tak, aby odpovídaly vzorovým tvarům. Dále popisuji metodu Snakes, kdy dochází k postupnému tvarování kontur až ke hraně objektu v obraze.

Ke konečné úpravě segmentovaných obrazů je použita matematická morfologie. Mým cílem bylo seznámit se s metodami segmentace obrazových signálů a vybrané metody pak zpracovat jako skripty v programovacím jazyce Matlab a jejich vlastnosti ověřit na snímcích.

Klíčová slova

Segmentace, prahování, hranové detektory, matematická morfologie, aktive shape models.

KRUMPHOLC, L. *Metody segmentace biomedicínských obrazových signálů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2009. 58s. Vedoucí diplomové práce Ing. Jiří Přinosil.

Abstract

This work deals with methods of segmentation of biomedical image signals. It describes, sums up and compares representative methods of digital image processing.

Segmentation based on parametric representation is one of the mentioned methods. So as the basic parameter can be chosen for example luminance and the final binary image is obtained by thresholding. Next described method is segmentation based on edge representation. This method can be divided into edge detection by the help of edge detectors and of Hough transformation. Edge detectors work with the first and second derivation.

The following method is region-based segmentation, which can be used for a image with noise. This category can be divided into three parts. The first one is segmentation via splitting and merging regions, when the image is split and the created regions are tested on a defined condition. If the condition is satisfied, the region merges and doesn't continue splitting. The second one is region growing segmentation, when adjacent pixels with a similar intensity of luminance are grouped together and create a segmented region. Third one is watershed segmentation algorithm based on the idea of water diffusion on uneven surface.

The last group of methods is segmentation via flexible and active contours. Here is described an active shape model proceeding from a possibility to deform models so that they match with sample shapes. Next I also describe method Snakes, where occurs gradual contour shaping up to the edge of the object in the image.

For the final editing is used mathematical morphology of segmented images. I aimed to meet methods of image signals segmentation, to cover the chosen methods as a script in programming language Matlab and to check their properties on images.

Keywords

Segmentation, thresholding, edge detectors, mathematical morphology, active shape models.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma „Metody segmentace biomedicinských obrazových signálů“ jsem vypracoval samostatně pod vedením vedoucího semestrálního projektu a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne

.....

podpis autora

Poděkování

Děkuji vedoucímu diplomové práce Ing. Jiřímu Přinosilovi za účinnou, metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování práce.

V Brně dne

.....

podpis autora

Obsah

Úvod	10
1 Matematická morfologie.....	11
1.1 Dilatace	11
1.2 Eroze	13
1.3 Otevření a uzavření.....	15
2 Segmentace založená na parametrickém vyjádření	17
2.1 Segmentace podle jasu.....	17
3 Segmentace na základě hranové reprezentace	18
3.1 Hranové detektory	18
3.1.1 Detekce pomocí první derivace	19
3.1.2 Detekce pomocí druhé derivace	23
3.2 Houghova transformace.....	24
4 Regionově orientovaná segmentace	27
4.1 Segmentace růstem oblastí	27
4.2 Segmentace dělením a slučováním oblastí	28
4.3 Segmentace algoritmem rozvodí	29
5 Segmentace pomocí pružných a aktivních kontur	30
5.1 Parametrické pružné kontury	30
5.1.1 Snakes	30
5.1.2 Nevýhody parametrických pružných kontur	31
5.1.3 Active shape models (ASM).....	33
5.2 Geometrické pružné kontury	37
6 Popis realizovaných algoritmů	39
6.1 Segmentace prahováním.....	39
6.2 Segmentace na základě hranové reprezentace	41
6.3 Segmentace růstem oblastí	42
6.4 Segmentace dělením a slučováním oblastí:	44
6.5 Aktive shape models:	45
7 Závěr	52
Seznam použité literatury	53
Seznam použitých veličin a symbolů	55
Seznam použitých zkratk	56
Seznam příloh	57

Seznam obrázků

Obr. 1.1:	Příklad dilatace	11
Obr. 1.2:	Dilatace jako isotropická expanze	12
Obr. 1.3:	Dilatace pro případ, kdy počátek není prvkem strukturního elementu.....	13
Obr. 1.4:	Příklad eroze	14
Obr. 1.5:	Eroze jako isotropické smrštění objektu.....	14
Obr. 1.6:	Originální obrázek a) a obrys b) jako rozdíl erodovaného a původního obrázku	14
Obr. 1.7:	Originální obraz (vlevo) a obraz po otevření (vpravo).....	15
Obr. 1.8:	Originální obraz (vlevo) a obraz po uzavření (vpravo)	16
Obr. 3.1:	Typy hran v obraze - step, ramp, line, roof	18
Obr. 3.2:	Ukázka průchodu nulovou hladinou.....	23
Obr. 3.3:	Houghova transformace přímky [9]	24
Obr. 3.4:	Příklad detekce [9].....	25
Obr. 3.5:	Ukázka popisu hranice [7].....	26
Obr. 4.1:	Dekompozice čtyřstromem [6]	28
Obr. 4.2:	Originální obraz a) a ukázky segmentace algoritmem rozvodí s různým rozlišením úrovní b),c),d) [6]	29
Obr. 5.1:	Ukázka parametrické pružné kontury [16]	32
Obr. 5.2:	Spojování hranic – změna topologie pohybujícího se rozhraní [10]	32
Obr. 5.3:	Reparametrizace [10].....	33
Obr. 5.4:	Příklad geometrické kontury [10].....	37
Obr. 6.1:	Originální obraz (vlevo) obraz po segmentaci prostým prahováním (vpravo) s parametrem <code>tresh=100</code>	39
Obr. 6.2:	Originální obraz (vlevo) obraz po segmentaci dvojitým prahováním (vpravo) s parametrem <code>tresh1=80</code> a <code>tresh2=100</code>	40
Obr. 6.3:	Originální obraz (vlevo) obraz po segmentaci polo prahováním (vpravo) s parametrem <code>tresh=80</code>	40
Obr. 6.4:	Originální obraz (vlevo) a výsledný obraz po použití Sobelova hranového detektoru (vpravo)	41
Obr. 6.5:	Výsledný obraz po použití Prewittova (vlevo) a Robertsova hranového operátoru (vpravo)	41
Obr. 6.6:	Výsledný obraz po použití Cannyho (vlevo) a Laplacian-Gaussian hranového operátoru (vpravo)	42
Obr. 6.7:	Originální obraz (vlevo) a obraz po průchodu segmentací růstem oblastí s parametrem <code>distance=0,05</code> (vpravo)	43
Obr. 6.8:	Obrazy po průchodu segmentací růstem oblastí s parametrem <code>distance=0,09</code> (vlevo) a s parametrem <code>distance=0,13</code> (vpravo)	43

Obr. 6.9:	Originál (vlevo) a obraz po segmentaci dělením a slučováním oblastí (vpravo) threshold=0,1, mindim=2 a parametr sdtresh=10.....	44
Obr. 6.10:	Obrazy po segmentaci dělením a slučováním oblastí threshold=0,1, mindim=4, sdtresh=10 (vpravo) a threshold=0,1, mindim=8, sdtresh=10 (vlevo).....	45
Obr. 6.11:	Ukázka vytvořeného profilového modelu	46
Obr. 6.12:	Tvary načtené z trénovací množiny.....	46
Obr. 6.13:	Tvary z trénovací množiny po zarovnání na střed.....	47
Obr. 6.14:	Tvary z trénovací množiny po zarovnání na střed a změně velikosti v proměnné Align_models (modře) a jejich průměrný tvar (červeně).....	47
Obr. 6.15:	Výřez vstupního obrazu se zobrazeným vstupním tvarem (vlevo) a tvar po prvním průchodu profilovým modelem (vpravo).....	49
Obr. 6.16:	Výřez vstupního obrazu se zobrazeným tvarem po prvním průchodu profilovým modelem (vlevo) a po následné úpravě tvarovým modelem (vpravo)	49
Obr. 6.17:	Výřez vstupního obrazu se zobrazeným vstupním tvarem a), tvarem po třetí b), třinácté c) a tvarem po třicáté první iteraci d)	50
Obr. 6.18:	Výřez vstupního obrazu se zobrazeným vstupním tvarem a), tvarem po třinácté b), třicáté c) a tvarem po padesáté první iteraci d)	51

Seznam tabulek

Tab. 2.1:	Konvoluční jádra hranových detektorů	20
Tab. 2.2:	Ukázky filtrů pro jednotlivé směry.....	22

Úvod

Počítačové zpracování obrazu je v praxi velmi důležité. Je to disciplína, která má už za sebou dlouholetou historii, a proto i široké pole využití. Zvláště v poslední době má velký význam v oblastech průmyslu, počítačové grafiky, zábavy a medicíny.

Segmentace obrazových dat představuje nedílnou součást zpracování digitálního obrazu. Touto problematikou se zabývá mnoho vědců a odborníků. Pokud by se chtěl s tímto problémem kdokoli seznámit podrobněji, je mu k dispozici řada odborné literatury zpracované hlavně v anglickém jazyce. Je to proto, že dochází k výměně názorů a spolupráci na mezinárodní úrovni.

V medicíně se segmentace využívá pro zvýraznění a hledání odlišných částí v obraze. Například u běžného rentgenového snímku dokážeme pomocí segmentace určit tvrdé a měkké tkáně nebo dutiny. Kostí jsou na snímcích zobrazeny bílou a světle šedou barvou, svaly šedou až tmavě šedou barvou a tělní dutiny jsou zobrazeny téměř černě. V praxi je snaha pomocí těchto metod prohlubovat teoretické základy humánní medicíny a tím co nejúčinněji pomáhat člověku.

Segmentace obrazu je proces, kdy dělíme vstupní obraz na jednotlivé oblasti a ty musí splňovat určité kritérium. Segmentaci můžeme rozdělit na dvě části. Úplná segmentace rozděluje obraz na odlišné oblasti, které představují objekty v obraze. Částečná segmentace rozděluje obraz na části, které mají společné vlastnosti, ale nedokáže přesně určit hledaný objekt. Ve skutečnosti oddělujeme pixely zkoumaných objektů v popředí od pixelů, které patří do pozadí obrazu. Patří sem také operace, kdy zkoumáme, jestli jsou v obraze obsaženy různé objekty, které budeme potřebovat pro rozpoznání, nebo další analýzy obrazu. Struktura obrazu může být velmi složitá, jednotlivé objekty se mohou překrývat, jednotlivé části obrazu mohou být nerovnoměrně osvětlené, tzn. že mohou obsahovat stíny. Segmentace obrazu a správný popis objektu proto patří mezi nejsložitější úkoly při zpracování obrazu. Tyto problémy můžeme vyřešit pomocí algoritmů založených buď na hledání podobností nebo hledání nespojitostí, ale můžeme použít i hybridní techniku. Do skupiny algoritmů, které hledají části obrazů pomocí kritéria podobnosti, patří např. algoritmy založené na postupném rozdělování nebo spojování oblastí. Další skupinou algoritmů jsou algoritmy založené na detekci nespojitostí a zde se jedná o hledání hran nebo extrakci linií. Nesmíme zapomenout ani na další způsob segmentace obrazů, který rozděluje obraz na dvouúrovňový černobílý snímek, a tím je prahování. V posledním desetiletí se pro řešení problémů segmentace často používá takzvaných aktivních kontur, které dosahují lepších výsledků u zašuměných obrazů, kde jiné metody selhávají. Tato metoda využívá teorii deformovatelných modelů, která spočívá v sestavení modelu a jeho přizpůsobování k obrazu, dokud nedosáhne rovnovážného stavu. Úkolem je navrhnout takový model, aby tento rovnovážný stav odpovídal poloze objektu v obraze, protože hranice modelu potom odpovídají segmentované hranici objektu.

1 Matematická morfologie

S novým zpracováním obrazů prostřednictvím matematické morfologie nás seznámili Francouzi Matheron a Serra. Poprvé se s ní setkáváme v šedesátých letech, jedná se o matematický aparát vycházející z algebry nelineárních operací, které předstihují tradiční lineární přístup. Využívá konvoluci bodových zdrojů představovaných Diracovými impulsy. Jedná se například o předzpracování obrazu, o segmentaci s důrazem na tvar hledaných objektů nebo o kvantitativní popis nalezených objektů. Operátory matematické morfologie se obvykle používají tam, kde je požadavek na krátký čas zpracování. Můžeme je využít v biologii, v materiálovém výzkumu, geologii, kriminalistice, v obrazové inspekci průmyslu, v rozpoznávání znaků a dokumentů apod..

1.1 Dilatace

Dilatace \oplus skládá body dvou množin pomocí vektorového součtu (též Minkowského množinový součet, například $(a,b)+(c,d)=(a+c,b+d)$). Dilatace $X \oplus B$ je bodovou množinou všech možných vektorových součtů pro dvojice pixelů, vždy pro jeden z množiny X a jeden z množiny B [3, 15]:


$$X \oplus B = \{p \in \mathcal{E}^2 : p = x + b, x \in X, b \in B\} \quad (1.1) [3]$$

Příklad dilatace:

$$X = \{(1,0), (1,1), (1,2), (2,2), (0,3), (0,4)\}$$

$$B = \{(0,0), (1,0)\}$$


$$X \oplus B = \{(1,0), (1,1), (1,2), (2,2), (0,3), (0,4), (2,0), (2,1), (2,2), (3,2), (1,3), (1,4)\}$$



Obr. 1.1: Příklad dilatace

Obrázek 1.2 znázorňuje dilataci pro reálný obraz. Vstupním obrazem (obr. 1.2 a)) jsou obratle páteře o velikosti 272×257 . Je použit strukturní element o rozměru 3×3 (obr. 1.2 c)). Výsledek dilatace je obrázek 1.2 b). Byl zde použit isotopický strukturní element, to znamená, že se morfologická transformace chová stejně ve všech směrech – objekty expandují. Objekty se rozrostly o jednu „slupku“ na úkor pozadí. Rovněž díry, které měly tloušťku jeden bod, se zaplnily.

Dilataci s isotopickým strukturním elementem 3×3 můžeme chápat jako transformaci, která změní všechny body v pozadí sousedící s objekty na body objektů.



Obr. 1.2: Dilatace jako isotropická expanze

Vlastnosti dilatace:

- Dilatace je komutativní operací

$$X \oplus B = B \oplus X \quad (1.2) [3]$$

- Dilatace je asociativní


$$X \oplus (B \oplus D) = (X \oplus B) \oplus D \quad (1.3) [3]$$

- Dilatace je invariantní vůči posunu

$$X_h \oplus B = (X \oplus B)_h \quad (1.4) [3]$$

- Dilatace je rostoucí transformace

$$\text{Je-li } X \subseteq Y, \text{ pak } X \oplus B \subseteq Y \oplus B \quad (1.5) [3]$$



Obr. 1.3: Dilatace pro případ, kdy počátek není prvkem strukturního elementu

Dilatace se používá samostatně k zaplnění malých děr, úzkých zálivů a jako stavební kámen složitějších operací. Dilatace také zvětšuje objekty. Pokud chceme zachovat jejich původní rozměr, kombinujeme dilataci s erozí [3, 15].

Obrázek 1.3 ukazuje výsledek dilatace v případě, kdy reprezentativní bod nebyl prvkem strukturního elementu. Výsledek se značně liší od vstupního obrazu, protože došlo k porušení souvislostí.

1.2 Eroze

Duální operací k dilataci je eroze. Ani jedna z těchto dvou funkcí není invertovatelná. Eroze \ominus skládá dvě množiny podle tohoto předpisu:

$$X \ominus B = \{p \in \mathcal{E}^2 : p + b \in X \text{ pro každé } b \in B\} \quad (1.6) [3]$$


Tento předpis udává, že pro každý bod obrazu p se ověřuje, jestli pro všechna možná $p+b$ leží výsledek v X . Pokud tomu tak je, zapisujeme v reprezentativním bodě do výsledného obrázku 1, v opačném případě nulu [3].

Obrázek 1.4 znázorňuje bodovou množinu X erodovanou strukturním elementem B , který není všesměrový. Svislá čára zmizí.

$$X = \{(1,0), (1,1), (1,2), (0,3), (1,3), (2,3), (3,3), (1,4)\}$$

$$B = \{(0,0), (1,0)\}$$

$$X \ominus B = \{(0,3), (1,3), (2,3)\}$$




Obr. 1.4: Příklad eroze

Obrázek 1.5 znázorňuje erozi isotropickým strukturním elementem 3×3 z obrázku 1.2 c) na stejném vstupním obrázku, jako je obrázek 1.2 a). Ve výsledku zmizely čáry tloušťky 1.



Obr. 1.5: Eroze jako isotropické smrštění objektu

V následujícím obrázku (obr. 1.6) snadno najdeme obrys objektu, a to odečtením erodovaného obrázku od původního obrázku:



Obr. 1.6: Originální obrázek a) a obrys b) jako rozdíl erodovaného a původního obrázku

Pokud potřebujeme zjednodušit struktury objektů, použijeme erozi. Objekty tloušťky 1 se ztratí a složitější objekt se rozdělí na několik jednodušších.

1.3 Otevření a uzavření

Platí, že dilatace a eroze nejsou navzájem inverzní zobrazení. Jejich kombinace představují další významné morfologické transformace, a to otevření a uzavření. Výsledkem obou kombinací je zjednodušený obraz, který obsahuje méně detailů.

Pokud je eroze následována dilatací, vzniká nová transformace – otevření. Otevření množiny X strukturním elementem B se označuje $X \circ B$ a je definována jako:

$$X \circ B = (X \ominus B) \oplus B \quad (1.7) [3]$$

Uzavření představuje způsob, kdy je dilatace následována erozí. Uzavření množiny X strukturním elementem B se označuje $X \bullet B$ a je definována jako:

$$X \bullet B = (X \oplus B) \ominus B \quad (1.8) [3]$$

Situace, kdy je obraz X otevřený vzhledem k B , nastává tehdy, když se obraz X nezmění po otevření strukturním elementem B .

Další varianta může nastat tehdy, když se obraz X nezmění po uzavření strukturním elementem B , to znamená, že je uzavřený vzhledem k B .



Obr. 1.7: Originální obraz (vlevo) a obraz po otevření (vpravo)

Na obrázku 1.7 je vidět, jak otevření oddělilo objekty spojené úzkou šíjí a tak zjednodušilo strukturu objektu.



Obr. 1.8: Originální obraz (vlevo) a obraz po uzavření (vpravo)

Na obrázku 1.8 uzavření spojilo objekty, které byly blízko u sebe, zaplnilo malé díry a vyhladilo obrys tím, že zaplnilo úzké zálivy. Pojmy „malý“, „blízký“ a „úzký“ jsou relativní vzhledem k velikosti strukturního elementu.

Otevření a uzavření izotropickým strukturním elementem se používá pro odstranění detailů v obraze, které jsou menší než strukturní element. Celkový tvar objektu se tak neporuší. Otevření a uzavření jsou invariantní vzhledem k posunutí strukturního elementu a jak otevření, tak uzavření jsou rostoucí transformace. Otevření je antiextenzivní ($X \circ B \subseteq X$) a uzavření je extenzivní ($X \subseteq X \bullet B$). Další vlastností otevření a uzavření je, že opakované použití těchto operací nemění předchozí výsledek [3, 15].

2 Segmentace založená na parametrickém vyjádření

2.1 Segmentace podle jasu

Jedná se o nejjednodušší segmentační metodu, ve které musíme stanovit meze (práh T), tzv. prahování, což znamená, že distribuce úrovně šedi v obraze může určit práh pro převod vstupního obrazu $f(i,j)$ na výstupní (segmentovaný) binární obraz $g(i,j)$.

Při prostém prahování vytváříme jen jeden práh T a tím dochází ke vzniku binárního obrazu $g(i,j)$, tzn. že obsahuje pouze dva typy pixelů- 1 nebo 0 [8].

$$g(i,j) = \begin{cases} 1 & \text{pro } f(i,j) > T \\ 0 & \text{jinak} \end{cases} \quad (2.1)$$

U dvojitého prahování jsou zvoleny dva prahy a jen oblasti mezi nimi jsou bílé.

$$g(i,j) = \begin{cases} 1 & \text{pro } f(i,j) \in \langle T_1, T_2 \rangle \\ 0 & \text{jinak} \end{cases} \quad (2.2)$$

Existuje také modifikace nazývaná poloprahování, kdy dochází k potlačování nezajímavých částí obrazu a zbylé části zůstávají beze změn.

$$g(i,j) = \begin{cases} f(i,j) & \text{pro } f(i,j) > T \\ 0 & \text{jinak} \end{cases} \quad (2.3)$$

Dalším způsobem je adaptivní prahování, které se liší od základního tím, že se liší hodnota prahu pro různé části obrazu a představuje tak funkci lokálních parametrů obrazu. Obraz nejdříve rozdělujeme do několika částí, pak pro každou část najdeme prahy (mohou být interpolovány) a nakonec provedeme prahování pro každou část s jejím konkrétním prahem [8].


$$g(i,j) = \begin{cases} 1 & \text{pro } f(i,j) > D \\ 0 & \text{jinak} \end{cases}, \quad (2.4)$$

kde D je jistá množina úrovní jasu.

3 Segmentace na základě hranové reprezentace

Základem metody hranové reprezentace je detekce hran. Představuje jednu z nejdůležitějších oblastí nižší úrovně zpracování obrazu. V realitě se jedná o velmi složitý a dosud stále nevyřešený problém. Hrany jsou místa obrazu, kde vzniká určitá nespojitost, většinou v jasů – hodnota jasů se prudce mění, ale může se objevit také v barvě nebo textuře a podobně. Každá hrana je reprezentovaná velikostí a směrem, a proto můžeme hranu chápat jako vlastnost obrazového bodu, který představuje funkci obrazu v okolí tohoto bodu. Při zkoumání obrazu se zaměřujeme hlavně na změny nebo přerušení v jasů obrazu, protože tak sledujeme fyzické rozmístění objektů v obraze. Nacházíme změny dvojího druhu – lokální a globální změny. Lokálním změnám jasů obrazu z jedné úrovně na druhou říkáme jasové hrany a globálním změnám říkáme jasové hraniční segmenty.

V obraze můžeme nalézt různé typy hran. Průběhu ideální hrany odpovídá skok (step). V reálných obrazech však dochází ke změně jasů postupně, proto zde nacházíme šikmou hranu (ramp). Pokud se šikmý a skokový průběh hran objeví v obraze vedle sebe, vznikají ještě další dva typy hran: linie (line) a střecha (roof) [8, 13].



Obr. 3.1: Typy hran v obraze - step, ramp, line, roof

Algoritmus detekce hran se dá rozdělit na tři fáze: filtrování
diferenciace
detekce

Pomocí filtrování může být šum vzniklý při vzorkování obrazu, kvantování, rozmazání nebo nevhodném nastavení kamery částečně odstraněn.

Diferenciace slouží ke zvýraznění oblastí v obraze kde je změna intenzity jasů obrazu významná. Detekce detekuje a lokalizuje body, kde je změna intenzity nejvýznamnější.

3.1 Hranové detektory

Rozlišujeme dvě hlavní skupiny metod detekce hran. Tyto metody využívají první derivaci nebo druhou derivaci. Při použití první derivace je výsledek porovnáván s prahem, který určuje, jedná-li se o hrany, či nikoli. U druhé derivace je zaznamenán výskyt hrany jen v tom případě, je-li prostorová změna v polaritě druhé derivace dostatečně významná [13].

3.1.1 Detekce pomocí první derivace

Detekce pomocí první derivace využívá rozdílů okolních pixelů obrazu. Nejjednodušší způsob je vypočítat derivaci pro řádky nebo sloupce zvlášť. Sousední pixely bereme zleva doprava nebo shora dolů.

Výsledný gradient vypočteme takto:

$$G(i,j) = \sqrt{G_R(i,j)^2 + G_S(i,j)^2} \quad (3.1) [13]$$

, kde $G(i,j)$ je výsledný gradientní obraz, $G_R(i,j)$ je gradient obrazu po detekci hran pomocí první derivace pro řádky a $G_S(i,j)$ je gradient obrazu po detekci hran pomocí první derivace pro sloupce.

Pokud se chceme vyhnout výpočetní složitosti, použijeme vzorec:

$$G(i,j) = |G_R(i,j)| + |G_S(i,j)| \quad (3.2) [13]$$

Tento způsob však může vést k rapidnímu zhoršení výsledku. Orientaci gradientu v obraze vzhledem k řádkům určíme jako:

$$\theta(i,j) = \arctan \frac{G_S(i,j)}{G_R(i,j)} \quad (3.3) [13]$$

Gradient vypočteme také jako konvoluci filtru s obrazem. Jednotlivé hranové detektory se pak liší právě tímto filtrem. Jádru filtru nám stanovuje, které body máme pro výpočet gradientu použít a jakou budou mít váhu. Nastavení jádra – jeho velikost a hodnoty, významně ovlivňují výsledné vlastnosti hranového detektoru. Impulsní charakteristiky filtrů můžeme zhlédnout v tabulce 2.1.

Tab. 2.1: Konvoluční jádra hranových detektorů

Operátor	Řádkový gradient	Sloupcový gradient
Pixel difference	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & -1 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$
Separated pixel difference	$\begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & -1 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix}$
Roberts	$\begin{bmatrix} 0 & 0 & -1 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$
Prewitt	$\frac{1}{3} \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$	$\frac{1}{3} \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$
Sobel	$\frac{1}{4} \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$	$\frac{1}{4} \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$
Frei-Chen	$\frac{1}{2+\sqrt{2}} \begin{bmatrix} 1 & 0 & -1 \\ \sqrt{2} & 0 & -\sqrt{2} \\ 1 & 0 & -1 \end{bmatrix}$	$\frac{1}{2+\sqrt{2}} \begin{bmatrix} -1 & -\sqrt{2} & -1 \\ 0 & 0 & 0 \\ 1 & \sqrt{2} & 1 \end{bmatrix}$

Velikost jádra filtru významně ovlivňuje citlivost na šum, a proto některé filtry mají velikost 5×5 i 7×7 .

Další skupinou hranových filtrů jsou detektory s váhovací funkcí Gaussovského tvaru. Argyle (3.4) a Macleod (3.5) navrhli filtry, které snižují váhy jednotlivých pixelů obrazu s jejich vzdáleností od středu.

Definice filtrů pomocí Gaussovské funkce se střední odchylkou $G(x,s)$ pro řádky (pro sloupce) jsou vzorce podobné):

$$\mathbf{H}_R(j,k) = \begin{cases} -2 \cdot G(x, \sigma_x) \cdot G(y, \sigma_y) & \text{pro } x \geq 0 \\ 2 \cdot G(x, \sigma_x) \cdot G(y, \sigma_y) & \text{pro } x < 0 \end{cases}, \quad (3.4) [13]$$

kde $\mathbf{H}_R(j,k)$ je impulsní charakteristika filtrů pro řádky.

$$\mathbf{H}_R(j,k) = [G(x + \sigma_x, \sigma_x) - G(x - \sigma_x, \sigma_x)] \cdot G(y, \sigma_y), \quad (3.5) [13]$$

Výsledná odezva gradientních operátorů se pak získá složením řádkových a sloupcových operátorů pomocí konvoluce:

$$\mathbf{H}(j,k) = \mathbf{H}_R(j,k) * \mathbf{H}_S(j,k) \quad (3.6) [13]$$

Další příklad je operátor první derivace Gaussovske funkce:

$$\mathbf{H}_R(j,k) = \frac{-\partial [\mathbf{G}(x, \sigma_x) \cdot \mathbf{G}(y, \sigma_y)]}{\partial x} = \frac{-x [\mathbf{G}(x, \sigma_x) \cdot \mathbf{G}(y, \sigma_y)]}{\sigma_x^2} \quad (3.7) [13]$$

Uvedené operátory pro zvýraznění hran byly vyvinuty heuristicky. Canny zvolil analytický přístup a jeho operátor je nastaven tak, aby co nejlépe vyhovoval následujícím podmínkám:

- dobrá detekce – poměr signál - šum by měl být co největší => nejmenší pravděpodobnost selhání výběru hrany
- dobrá lokalizace – vybrané hranové body leží co nejblíže středu hrany
- jedinečná odezva – existence jedinečné odezvy na skutečnou hranu

Realizace Cannyho operátoru kvůli složitosti není možná, proto se používají různé způsoby pro jeho vytvoření, které se snaží co nejvíce přiblížit stanoveným podmínkám. Příkladem může být využití první derivace Gaussovske funkce, adaptivního prahování a techniky potlačení nemaximálních hodnot [13].

Výpočty, které jsme dělali doposud, jsou výpočty gradientu ve dvou kolmých směrech. Další způsob výpočtu gradientu ve více směrech je výpočet s použitím konvoluce a šablon. Tento gradient můžeme vypočítat takto:

$$\mathbf{G}(j,k) = \text{MAX} \{ |\mathbf{G}_1(j,k)|, \dots, |\mathbf{G}_m(j,k)| \}, \quad (3.8) [13]$$

kde je

$$\mathbf{G}_m(j,k) = \mathbf{F}(j,k) * \mathbf{H}_m(j,k) \quad (3.9) [13]$$

Úhel hrany je pak určen směrem největšího gradientu.


Tab. 2.2: Ukázky filtrů pro jednotlivé směry

Gradient direction	Prewitt compass gradient	Kirsch	Robinson 3-level	Robinson 5-level
East H_1	$\begin{bmatrix} 1 & 1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & -1 \end{bmatrix}$	$\begin{bmatrix} 5 & -3 & -3 \\ 5 & 0 & -3 \\ 5 & -3 & -3 \end{bmatrix}$	$\begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$
Northeast H_2	$\begin{bmatrix} 1 & -1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} -3 & -3 & -3 \\ 5 & 0 & -3 \\ 5 & 5 & -3 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 & -1 \\ 1 & 0 & -1 \\ 1 & 1 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 & -2 \\ 1 & 0 & -1 \\ 2 & 1 & 0 \end{bmatrix}$
North H_3	$\begin{bmatrix} -1 & -1 & -1 \\ 1 & -2 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & -3 \\ 5 & 5 & 5 \end{bmatrix}$	$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$
Northwest H_4	$\begin{bmatrix} -1 & -1 & 1 \\ -1 & -2 & 1 \\ 1 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & 5 \\ -3 & 5 & 5 \end{bmatrix}$	$\begin{bmatrix} -1 & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} -2 & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & 2 \end{bmatrix}$
West H_5	$\begin{bmatrix} -1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & 1 & 1 \end{bmatrix}$	$\begin{bmatrix} -3 & -3 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & 5 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$
Southwest H_6	$\begin{bmatrix} 1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & -1 & 1 \end{bmatrix}$	$\begin{bmatrix} -3 & 5 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & -3 \end{bmatrix}$	$\begin{bmatrix} 0 & 1 & 1 \\ -1 & 0 & 1 \\ -1 & -1 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{bmatrix}$
South H_7	$\begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ -1 & -1 & -1 \end{bmatrix}$	$\begin{bmatrix} 5 & 5 & 5 \\ -3 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix}$	$\begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$	$\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$
Southeast H_8	$\begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & -1 \\ 1 & -1 & -1 \end{bmatrix}$	$\begin{bmatrix} 5 & 5 & -3 \\ 5 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix}$	$\begin{bmatrix} 1 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -1 \end{bmatrix}$	$\begin{bmatrix} 2 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -2 \end{bmatrix}$
Scale factor	$\frac{1}{5}$	$\frac{1}{15}$	$\frac{1}{3}$	$\frac{1}{4}$

Tento gradientní obraz se může dále zpracovat například pomocí morfologických operátorů pro ztenčení hran nebo jejich skeletonizaci. Uvedené operátory mají velkou závislost na velikosti objektu v obraze a citlivost na šum, což je nevýhodné.

3.1.2 Detekce pomocí druhé derivace

Pokud se rozhodneme pro použití druhé derivace, je lepší se přiklonit k použití detekce průchodu nulovou hladinou, protože je mnohem jednodušší než nalézt extrém.



Obr. 3.2: Ukázka průchodu nulovou hladinou

Druhou derivaci využívá Laplacian a platí, že má stejné vlastnosti ve všech směrech, z toho vyplývá, že je invariantní vůči rotaci:

$$\nabla^2 f(j,k) = \frac{\partial^2 f(j,k)}{\partial^2 j} + \frac{\partial^2 f(j,k)}{\partial^2 k} \quad (3.10) [13]$$

Normalizovaná impulsová odezva Laplacianu:

$$\mathbf{H} = \frac{1}{4} \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

4-okolí

$$\mathbf{H} = \frac{1}{8} \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

8- okolí

$$\mathbf{H} = \frac{1}{8} \begin{bmatrix} -2 & 1 & -2 \\ 1 & 4 & 1 \\ -2 & 1 & -2 \end{bmatrix}$$

separabilní s 8- okolím

Nevýhodou Laplacianu je dvojitá odezva na některé hrany v obraze. Podle Marr a Hildrith lze vypočítat Laplacian Gaussové funkce takto:

$$\mathbf{H}(x,y) = -\nabla^2 \{ \mathbf{G}(x,\sigma) \cdot \mathbf{G}(y,\sigma) \} \quad (3.11) [13]$$

Tato funkce je aproximovatelná funkcí diferenciálu Gaussové funkce:

$$\mathbf{H}(x,y) = \mathbf{G}(x,\sigma_1) \cdot \mathbf{G}(y,\sigma_1) - \mathbf{G}(x,\sigma_2) \cdot \mathbf{G}(y,\sigma_2) \quad (3.12) [13]$$

Další nevýhody, které vznikají při použití druhé derivace, detekující průchod nulovou hladinou jsou:

- velké vyhlazení obrazu
- ztráta ostrých rohů
- sklon vytvářet uzavřené smyčky hran

3.2 Houghova transformace

Houghova transformace popisuje hrany s větší přesností, ale je výpočetně mnohem náročnější. Musíme znát analytický popis tvaru hledaného objektu, to znamená detekci známého jednoduchého tvaru – přímku, kružnici, elipsu nebo trojúhelník. Při použití Houghovy transformace dostáváme nejlepší výsledky při použití na binární (naprahovaný) vyhranovaný snímek. Velkou výhodou je, že segmentace není příliš citlivá na porušená data a šum a je použitelná i při částečném zakrytí objektu. Jedná se o transformaci z Kartézského souřadnicového systému do polárního [8, 9].


Parametrické vyjádření přímky:

$$\rho = x \cdot \cos \theta + y \cdot \sin \theta, \quad (3.13) [13]$$

ρ je normalizovaná vzdálenost přímky od počátku

θ je úhel vzhledem k ose x

Body obrazu vytvářejí křivky v parametrickém prostoru. Pokud vybereme body z jedné přímky, křivky v parametrickém prostoru se nejčastěji protínají právě v bodě, který reprezentuje parametry hledané přímky.




Obr. 3.3: Houghova transformace přímky [9]

Nevýhodou této metody je problém přesnosti. Blízké rovnoběžné čáry mohou vlivem diskretizace vytvořit jen jedno maximum. Může nastat také zkreslení, které „zakřiví“ přímky, tím vznikne v parametrickém prostoru více maxim, které představují několik přímek. Metoda také neříká nic o počátku nebo konci křivek a tím získáváme například přímky místo úseček. Pokud použijeme hodnotu ρ již v průběhu detekce hran, docílíme urychlení algoritmu [9].

Parametrické vyjádření kružnice:

$$\begin{aligned}x &= a + r \cdot \cos \alpha \\y &= b + r \cdot \sin \alpha\end{aligned}\tag{3.14} [9]$$


Hledáme parametry a , b (souřadnice středu) a r (poloměr), to znamená, že výpočet bude náročnější, protože Houghův prostor má tři dimenze. Pokud známe alespoň jeden parametr (postačí i odhad), můžeme značně omezit interval hledání.



Obr. 3.4: Příklad detekce [9]

Stejný princip můžeme použít i pro křivky, elipsy a pro další obrazce, které můžeme popsat parametricky.

Takzvanou Obecnou Houghovu transformaci můžeme použít i na detekci tvarů, které nejdou přímo popsat parametricky. Pomocí explicitního seznamu všech bodů hranice získáme pozice všech pixelů vztažených k referenčnímu bodu – například k těžišti [8].



Obr. 3.5: Ukázka popisu hranice [7]

4 Regionově orientovaná segmentace

Tyto metody jsou efektivnější pro zašuměný obraz, protože je-li v obraze mnoho šumu, hranové detektory obtížně detekují hrany. Hlavním segmentačním kritériem nálezů oblastí v obraze je homogenita oblasti, jejím kritériem mohou být: úroveň šedi, barva, textura, tvar, model apod.

4.1 Segmentace růstem oblastí

Tato metoda je známá nejjednodušším výpočtem - sousední pixely s podobnou intenzitou jasu jsou seskupovány k sobě a vytvářejí segmentovanou oblast. Při segmentaci rozdělíme obraz nejdříve na jednotlivé pixely. Pak odstraníme mezi pixely slabé hrany, tzn. že jednotlivé oblasti spojíme do větších celků, pokud dodržíme definovaná kritéria. Jednotlivé metody segmentace růstu oblastí se mohou lišit pravidly pro počáteční rozdělení oblastí i kritérii pro jejich následné spojování. Výsledek spojování závisí i na pořadí v jakém jsou oblasti spojovány [8, 13].

Parametrem ovlivňujícím proces spojování může být například síla společné hranice mezi sousedními oblastmi. Pokud je hranice slabá, může být tzv. rozpuštěna a oblasti se spojí. Pro stanovení síly hrany se používá tzv. super-grid, obsahuje i informace o rozdílu hodnot sousedních pixelů (s_i, s_j). Sílu hrany pak vypočítáme:

$$v_{i,j} = \begin{cases} 1, & s_{i,j} < T_1 \\ 0, & \text{ostatní} \end{cases}, \quad (4.1) [13]$$

kde T_1 je práh určující, kdy se už jedná o silnou, popřípadě slabou hranu.

Další pravidlo je založeno na testování délky obvodu jednotlivých regionů (l_i, l_j) a jejich společné hranice:

$$\frac{W}{\min(l_i, l_j)} < T_2, \quad (4.2) [13]$$

kde W je počet slabých hran společné hranice.


Posledním uvedeným kritériem je:

$$\frac{W}{l} < T_3, \quad (4.3) [13]$$

kde l je délka společné hrany.

4.2 Segmentace dělením a slučováním oblastí

Tato metoda rozdělí celý obraz do oblastí, které se vzájemně nepřekrývají. Toto pyramidové rozdělení obrazu umožňuje také jeho úsporný a efektivní popis. Obraz je postupně rozdělován a nově vzniklé oblasti jsou testovány, jestli splňují danou podmínku. Pokud je tato podmínka splněna, oblasti se sloučí a dále se už nedělí. Pokud tato podmínka splněna není, dělí se dále na podoblasti. Nejčastějším a nejefektivnějším způsobem dělení je dělení obrazu na čtverce, k nim připojujeme popis pomocí struktury, které se říká čtyřstrom, proto se této metodě říká dekompozice čtyřstromem.



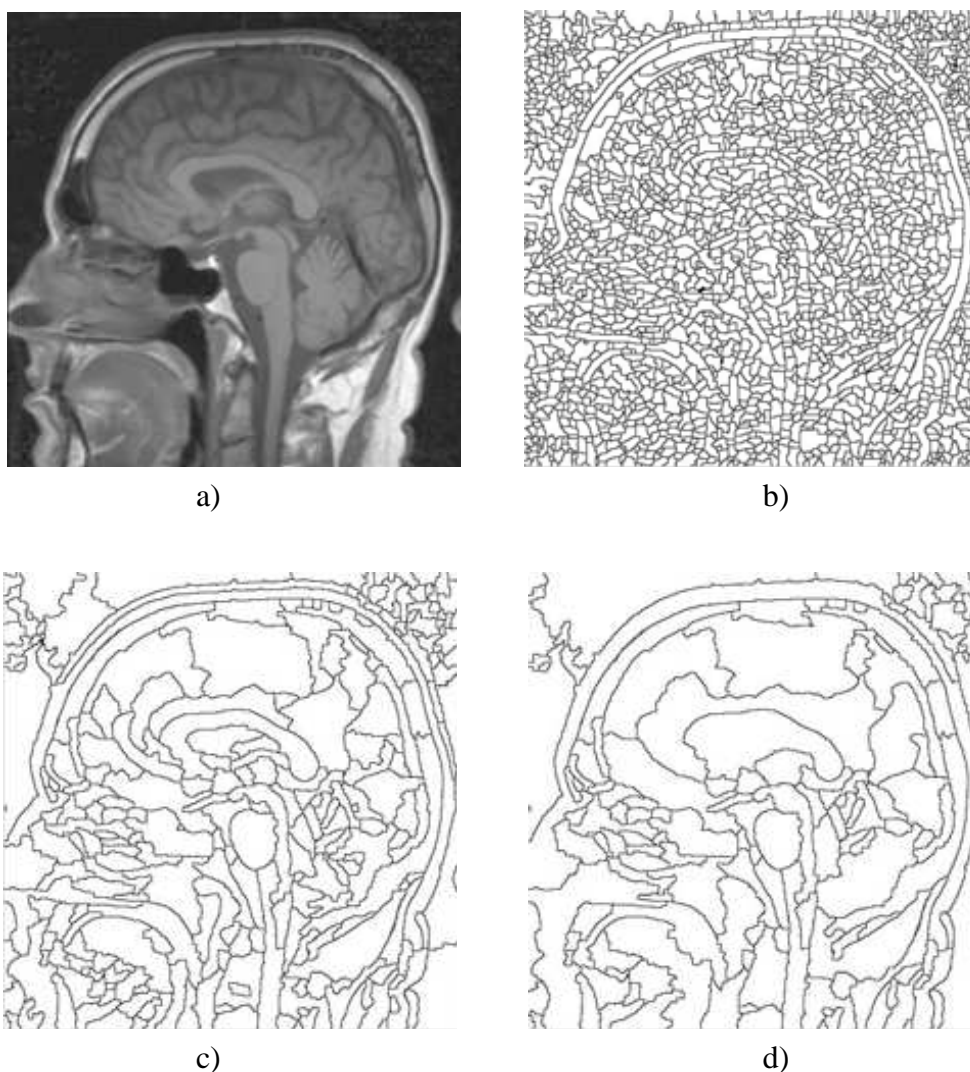
Obr. 4.1: Dekompozice čtyřstromem [6]

Obraz je kořen stromu. Ten se dělí na čtyři kvadranty, u kterých se zjišťuje podmínka stejnorodosti. Pokud určitá oblast podmínku splňuje, znamená to, že se už dále nedělí. Pokud oblast podmínku nesplňuje (např. oblast 0 na obrázku 4.1), musí se rozdělit opět na čtyři části. Tento proces se opakuje do té doby, dokud je co dělit. Dělení však můžeme ukončit i dříve, pokud byla vytvořena podmínka, aby hloubka stromu nepřekročila určitou mez. Pokud tomu tak není, je dekompozice ukončena až nalezením všech čtverců splňujících podmínku. Na závěr nám vzniknou bloky různých velikostí. Informace o blocích nalezneme v uzlech stromu [8, 13].

4.3 Segmentace algoritmem rozvodí

Tato metoda je založena na představě rozlévání vody na nerovnoměrný povrch, odtud vychází i její název „rozvodí“. Obraz je chápán jako terén, který je postupně zaplavován vodou. U zkoumaného obrazu se zaměřujeme na povrch a jeho výšku, tmavé barvy představují nížiny a světlé barvy kopce. Metoda se nejdříve zaměřuje na nejnižší body nížin. Hladina vody stoupá, v místech, kde by se voda ze dvou různých povodí mohla slít, jsou vytvořeny hráze. Postupné zaplavování obrazu je zastaveno ve chvíli, kdy dosáhneme nejvyššího bodu v terénu, to znamená, že nám vznikne jedna vodní plocha, která obsahuje celou oblast.

Pokud bychom si místa, kde došlo ke styku hladin ze dvou povodí označili jako hranici, rozdělili bychom obraz na jednotlivé oblasti [8, 13].



Obr. 4.2: Originální obraz a) a ukázky segmentace algoritmem rozvodí s různým rozlišením úrovní b),c),d) [6]

5 Segmentace pomocí pružných a aktivních kontur

Aktivní kontury dělíme na parametrické pružné kontury a geometrické pružné kontury. Toto rozdělení představuje způsob reprezentace pohybující se kontury – křivky, nebo povrchu.

5.1 Parametrické pružné kontury

5.1.1 Snakes

Aktivní kontury (snakes) představují metodu určování hranic mezi oblastmi, kdy dochází k postupnému tvarování kontur až ke hraně objektu v obraze. Modelem aktivní kontury může být například kružnice, která se deformuje vlivem takzvaných vnitřních, obrazových a vnějších sil. Vnitřní síly zajišťují hladkost průběhu, to znamená, že každý bod rozhraní se pohybuje ve směru normálového vektoru rychlostí úměrnou křivosti hranice v daném bodě. Obrazové síly jsou určeny ze vstupních dat a tvarují konturu směrem ke hraně objektu. Vnější síly, které jsou zadány uživatelem, urychlují pohyb modelu a umožňují mu opustit lokální minima [13].

Jde o výpočet vnitřní a vnější energie „snakes“ a nalezení jeho pozice s minimální celkovou energií. Výsledná pozice aktivní kontury se shoduje s lokálním minimem energie kontury.

Energetická funkce je definována:

$$\int_0^1 E_{\text{snake}}(v(s))ds = \int_0^1 [E_{\text{internal}}(v(s)) + E_{\text{image}}(v(s)) + E_{\text{constrain}}(v(s))]ds \quad (5.1) [11]$$

- $v(s)$ je parametrická křivka
- s je délka křivky
- E_{internal} je vnitřní energie křivky způsobená zakřivením jako její první a druhá derivace

$$E_{\text{internal}} = \alpha(t) \frac{\partial v(t)}{\partial t} + \beta(t) \frac{\partial^2 v(t)}{\partial^2 t}, \quad (5.2) [11]$$

Váhové funkce $\alpha(t)$ a $\beta(t)$ definují hladkost a pružnost kontury. Mají vliv na tvar kontury – například v ostrých zlomech, kde je možno regulovat přilínání na hrany v obraze, nebo vytvářet zaoblený tvar křivky.

Vnější energie E_{image} se skládá z více složek. Složky E_{line} , E_{edge} a E_{term} kvantifikují matematicky snadno popsitelné detaily obrazu.

$$E_{\text{image}} = w_{\text{line}} E_{\text{line}} + w_{\text{edge}} E_{\text{edge}} + w_{\text{term}} E_{\text{term}}, \quad (5.3) [11]$$

E_{line} určuje přitažlivost kontury k světlejším nebo tmavším částem obrazu podle váhového faktoru w_{line} .

$$E_{\text{line}} = f(v(t)), \quad (5.4) [11]$$

E_{edge} tvaruje kontury k hranám, tzn. k místům s vysokou hodnotou velikosti gradientu. Může se stát, že v místě největšího gradientu (energetického minima) se vyskytuje šum, místo je méně výrazné nebo příliš vzdálené od počáteční kontury, a proto je vhodné pro lepší konvergenci před samotným výpočtem obraz rozmazat nebo využít speciální hranový filtr.

$$E_{\text{edge}} = -|\nabla f(v(t))|^2 \quad (5.5) [11]$$

E_{term} detekuje ostré hrany a konce hran pomocí zkoumání křivosti. Křivost počítáme na rozmazaném obraze, protože nesmíme zapomenout na předpokládaný šum. V případě, kdy kontura kopíruje rovnou nebo hladkou hranu, je celková hodnota E_{term} malá.


$E_{\text{constrain}}$ reprezentuje externí síly, které mohou znázorňovat interaktivní požadavky uživatele na deformaci modelu.

5.1.2 Nevýhody parametrických pružných kontur

Parametrická pružná kontura je definovaná pomocí množiny bodů:

$$C(t) = \{(x(s, t), y(s, t)) | 0 \leq s \leq 1\} \quad (5.6) [10]$$


Podstata této metody spočívá ve volbě počáteční hranice a ve vyhledání vektoru \mathbf{p} , který ovlivňuje tvar hranice do žádaného tvaru na základě obsahu obrazu.



Obr. 5.1: Ukázka parametrické pružné kontury [16]

Mezi jednu z největších nevýhod parametrického přístupu patří nemožnost rozšíření do více dimenzí. Řada metod dává totiž uspokojivé výsledky pouze ve dvojrozměrném prostoru, ale problém nastává při rozšíření do třech dimenzí. Důvodem je parametrické vyjádření a použití rovnice pro pohyb rozhraní, protože rozšíření do třetí dimenze znamená nárůst složitosti implementace, která není jednoduchá.


Další potíže nastanou při změně topologie hranice. Při pohybu se oddělené hranice určitých oblastí mohou spojovat, rozdělovat, nebo dokonce zanikat. Proto musíme při výpočtu používat složité postupy, které tyto hranice určí a vyhodnotí [10].



Obr. 5.2: Spojování hranic – změna topologie pohybujícího se rozhraní [10]

Posledním příkladem vad v parametrickém přístupu je reparametrizace. Diskretizovaná křivka je určena sadou rovnoměrně rozmístěných bodů hranice. Platí, že zde existují vztahy, kterými z hodnot množiny $C(t)$ vypočítáme pomocí aproximace parciální derivace hodnotu množiny $C(t+\Delta t)$. Pro tento výpočet v určitém bodě byly použity informace o pozicích jeho sousedů. V případě složitějšího tvaru hranice se při pohybu mohou některé sousední body křivky vzájemně přibližovat, nebo oddalovat, což je znázorněno na obrázku 5.3. Hodnoty nové křivky neodpovídají sadě rovnoměrně rozmístěných bodů, a proto musíme

provést její reparametrizaci. Kdybychom tento krok neprovedli, vznikaly by chyby, které by vedly k nesprávným výsledkům nebo dokonce k numerickému selhání metody po několika iteracích [8, 10].



Obr. 5.3: Reparametrizace [10]

5.1.3 Active shape models (ASM)

Aktivní tvarový model vychází z toho, že model by mělo být možné deformovat pouze tak, aby odpovídal vzorovým tvarům z trénování množiny. Pro naše účely budeme uvažovat tvar jako $n \times 2$ uspořádanou sadu bodů, to jest pole s x a y souřadnicemi. Jestliže tento tvar přesuneme, zvětšíme nebo otočíme, obdržíme stále stejný tvar. Hrany v okolí bodů nejsou součástí tvaru, ale mohou nést informaci o uspořádání bodů. V praxi není vhodné reprezentovat tvar jako $n \times 2$ pole s x a y souřadnicemi, ale častěji jako $2n \times 1$ vektor – všechny x souřadnice následovány y souřadnicemi. Tato reprezentace je také užita v tomto popisu. Vzdálenost dvou bodů vypočítáme jako euklidovskou vzdálenost mezi těmito body a vzdálenost mezi dvěma tvary je poté součet vzdáleností mezi odpovídajícími si body. Prokrustovská vzdálenost mezi dvěma tvary x_1 a x_2 je rovna střední kvadratické hodnotě vzdáleností mezi odpovídajícími si body tvarů $\sqrt{(x_1 - x_2)(x_1 - x_2)}$ po zarovnání. Centroid \bar{x} tvaru x je průměrem pozic bodů. Velikost tvaru vypočítáme jako střední kvadratickou vzdálenost mezi body tvarů a centroidem [12].

Zarovnání modelů

Modely mohou být zarovnány k dalším modelům aplikací transformace, která udává minimální vzdálenost mezi tvary. V našem případě přicházejí v úvahu transformace, jako je

změna velikosti, otočení a lineární posun. Tyto transformace nazýváme také jako podobnostní transformace. Podobnostní transformace T , která rotuje bod (x,y) o θ , změni její velikost s -krát a posune bod o x_{posun} a y_{posun} je:

$$T\begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} x_{\text{posun}} \\ y_{\text{posun}} \end{pmatrix} + \begin{pmatrix} s \cdot \cos(\theta) & s \cdot \sin(\theta) \\ -s \cdot \sin(\theta) & s \cdot \cos(\theta) \end{pmatrix} \quad (5.7) [12]$$

Přesné zarovnání můžeme považovat pro některé body za více důležité než pro ostatní, a proto můžeme body zarovnávat také s různými vahami.

Zarovnávací algoritmus:

- výběr referenčního tvaru (obvykle první)
- posuneme každý tvar tak, aby byl vycentrován na počátek
- změníme velikost referenčního tvaru na jednotkovou velikost, tento tvar $\overline{x_0}$ nazýváme průměrný tvar
- opakujeme dokud se mění průměrný tvar
 - seřadíme všechny tvary k průměrnému tvaru
 - přepočítáme průměrný tvar ze zarovnaných tvarů
 - omezíme stávající průměrný model (zarovnání k $\overline{x_0}$, zarovnáme k jednotkové velikosti)

Postup ASM

Následující dvě sekce popisují dvě složky ASM:

- Tvarový model
- Profilový model

ASM je prvně natrénována na sadě ručně označených obrázcích. To znamená že někdo musel všechny trénovací obrázky projít a označit, což musí být provedeno před začátkem trénování. Po výcviku můžeme ASM použít k nalezení tvarů. Hlavní myšlenkou je zkusit najít každý orientační bod nezávisle, poté upravit pozici v případě potřeby. Právě proto je tato metoda konstruována ze dvou částí.

1) Profilový model

Jedná se o vytvoření profilového modelu, který popisuje parametry obrazu v okolí orientační značky, pro každý orientační bod. Model specifikuje, jak by mělo okolí bodů vypadat. Během výcviku vzorkujeme oblast v okolí bodů ve všech trénovacích obrázcích abychom vytvořili profilový model. V průběhu hledání vzorkujeme oblast sousedství

pokusných bodů a přemisťujeme body na pozice, které nejlépe odpovídají profilovému modelu. Tímto generujeme pokusně body pro nový tvar.

2) Tvarový model

Tvarové modely definují soubor povolených tvarů. V našem případě obsahují tvarové modely stálý počet bodů. Budeme používat modely rozložení bodů, které definují přípustné skupiny bodů z trénování množiny a využívají hlavní složky k sestavení modelu. Během hledání se tvarový model přizpůsobuje tvaru navrhovanému profilovým modelem, aby se přizpůsobil pravému tvaru. Tento krok je velmi důležitý, protože profilové schody nejsou věrohodné [12].

Algoritmus pro řešení s použitím obou modelů:

- vytvoření základního tvaru a lokalizace hledaného objektu v obraze
- opakujeme, dokud se model nepřizpůsobí hledanému tvaru
 - návrh nového tvaru profilovým vyhledáváním kolem každého bodu
 - zarovnáme model tak, aby vyhovoval tvarovému modelu

Tvarový model

Funkce tvarového modelu spočívá v přeměně tvaru navrženého profilovým modelem na přípustný tvar určený z trénovací množiny. Před vytvořením tvarového modelu jsou trénovací modely seřazeny. Tvarový model obsahuje průměrný tvar a přípustné deformace tohoto modelu:

$$\hat{\mathbf{x}} = \bar{\mathbf{x}} + \Phi \mathbf{b} \quad (5.8) [12]$$

- $\hat{\mathbf{x}}$ je vytvořený tvarový vektor
- $\bar{\mathbf{x}}$ je průměrný tvar – průměr seřazených trénovacích tvarů \mathbf{x}_i je definován jako:

$$\bar{\mathbf{x}} = \frac{1}{n_{\text{tvarů}}} \sum_{i=1}^{n_{\text{tvarů}}} \mathbf{x}_i \quad (5.9) [12]$$

- Φ je matice vlastních vektorů kovarianční matice S_s z trénovacích bodů

PCA (Principal Component Analysis)

Cílem analýzy hlavních komponent je transformace dat z původních proměnných \mathbf{x}_i do menšího počtu latentních proměnných \mathbf{y}_i . Tyto proměnné mají vhodnější vlastnosti, je jich výrazně méně, vystihují téměř celou proměnlivost původních proměnných a jsou vzájemně

nekorelované. PCA zajišťuje transformaci, která umožňuje rekonstruovat transformované vektory $\tilde{\mathbf{x}}_l$ s minimální chybou.

$$\varepsilon = \frac{1}{2} \sum_{i=1}^l \|\tilde{\mathbf{x}}_l - \tilde{\mathbf{x}}_i\|^2, \text{ kde } \tilde{\mathbf{x}}_l = \mathbf{P}^T \cdot \mathbf{y}_l. \quad (5.10) [1]$$

Matici \mathbf{P} je možné získat z L trénovacích dat reprezentovaných vektory \mathbf{x}_l , kde $l = 1 \dots L$.

Transformace příznakového vektoru potom vychází ze vzorce:

$$\mathbf{y}_l = \mathbf{P} \cdot \mathbf{x}_l. \quad (5.11) [1]$$

Jestliže máme trénovací množinu $\{\mathbf{x}_1, \dots, \mathbf{x}_l\}$ v prostoru dimenze D , pak metodou PCA získáme matici \mathbf{P} , jejíž pomocí můžeme nový vektor \mathbf{x} transformovat na vektor \mathbf{y} s dimenzí $d \ll D$. Nejprve je vypočítána střední hodnota a variance z množiny trénovacích vektorů

$$m_c = \frac{1}{L} \sum_{l=1}^L x_{l,c} \quad (5.12) [1]$$

$$\delta_c^2 = \frac{1}{L} \sum_{l=1}^L (x_{l,c} - m_c)^2, \quad c=1, \dots, d \quad (5.13) [1]$$

a poté kovarianční matice \mathbf{S}_s dimenze $D \times D$.

$$S_s = \frac{1}{L} \sum_{l=1}^L \frac{(x_{l,c1} - m_{c1})}{\delta_{c1}} \cdot \frac{(x_{l,c2} - m_{c2})}{\delta_{c2}}, \quad c1, c2=1, \dots, d \quad (5.14) [1]$$

Nyní provedeme rozklad kovarianční matice \mathbf{S}_s podle vzorce

$$\mathbf{S}_s = \mathbf{\Phi} \cdot \mathbf{V} \cdot \mathbf{\Phi}^T, \quad (5.15) [1]$$

kde $\mathbf{\Phi}$ představuje matici vlastních vektorů \mathbf{S}_s a \mathbf{V} je diagonální matice, která má na diagonále vlastní čísla matice \mathbf{S}_s . Matici \mathbf{P} získáme tak, že vybereme D největších vlastních čísel z matice \mathbf{V} a jim odpovídající vlastní vektory.

Profilový model

Abychom vytvořili profilový vektor \mathbf{g} v orientačních bodech, vzorkujeme obraz podél kolmice ke spojnici dvou bodů. Postup vytváření profilového modelu:

- nastavíme každý prvek profilového vektoru na šedotónový
- nahradíme každý profilový prvek gradientem intenzity, to provedeme nahrazením profilového prvku v každé pozici i rozdílem mezi i prvkem a $i-1$ prvkem

- podělíme každý prvek výsledného vektoru sumou absolutních velikostí všech prvků vektoru

Během hledání vytváříme v každém orientačním bodě několik profilových modelů tak, že vzorkujeme obrázky v okolí orientačního bodu. Každý vyhledávací profil je umístěn v malých kladných nebo záporných posunutích kolem orientačního bodu. Typicky vytváříme profily v rozpětí ± 3 body. Vzdálenost mezi vyhledávacím profilem \mathbf{g} a modelem průměrného modelu $\bar{\mathbf{g}}$ se počítá pomocí Mahalanobisovy vzdálenosti jako:


$$Vzdálenost = (\mathbf{g} - \bar{\mathbf{g}})^T \mathbf{S}_g^{-1} (\mathbf{g} - \bar{\mathbf{g}}) \quad (5.16) [12]$$

Střed profilu, který má tuto vzdálenost nejmenší, je místem pro novou navrhovanou pozici orientačního bodu. Tento proces se opakuje pro každý orientační bod před předáním kontroly zpět ke tvarovému modelu.

5.2 Geometrické pružné kontury

Základem geometrických pružných kontur je křivka $C(t)$ jako nulová vrstevnice zadané funkce Φ , která je dána pevně zvolenou pravidelnou sítí bodů v prostoru R^2 . Dimenze této funkce Φ je vždy o jeden řád vyšší než dimenze pohybujícího se rozhraní.

Na obrázku 5.4 je funkce $\Phi(x,y,t)$ znázorněná jako funkce dvou prostorových proměnných a jedné časové proměnné t . Normálový vektor \vec{N} a rychlost F znázorňuje pohyb hranice v rámci vývoje celé funkce Φ a výsledkem tohoto pohybu je určení nové nulové vrstevnice.



Obr. 5.4: Příklad geometrické kontury [10]

Geometricky pružné kontury mají řadu výhod ve srovnání s parametricky pružnými konturami. Tuto metodu lze využít i při rozšíření do více dimenzí, protože parciální diferenciální rovnice zde zůstává beze změny. To znamená, že pohyb povrchu v trojrozměrném prostoru je znázorněn pohybem hyperplochy stejnou rovnicí jako pohyb křivky v rovině. Při změnách topologie se pohybující rozhraní $C(t)$ slučují, dělí a zanikají naprosto přirozeně bez našeho zásahu. Dále můžeme lehce zjistit, zda daný bod p přísluší do pohybujícího se rozhraní $C(t)$ pomocí funkční hodnoty $\Phi(p,t)$. Je-li $\Phi(p,t)<0$, leží bod P uvnitř hranice, v opačném případě se bod P nachází vně pohybujícího se rozhraní [8, 10].

Základní geometrické vlastnosti hranice jsou dány normálovým vektorem a křivostí pohybujícího se rozhraní. Dají se snadno vyjádřit.

Normálový vektor v daném bodě rozhraní je dán vztahem:

$$\vec{N} = \frac{\nabla\Phi}{|\nabla\Phi|} \quad (5.17) [10]$$

Křivost rozhraní je definována jako divergence normálového vektoru $\vec{N}=(n_1,n_2)$:

$$k = \nabla \cdot \vec{N} = \frac{\partial n_1}{\partial x} + \frac{\partial n_2}{\partial y}, \quad (5.18) [10]$$


proto v konvexních oblastech je $k>0$, v konkávních oblastech je $k<0$ a v rovných oblastech je $k=0$.

6 Popis realizovaných algoritmů

V této kapitole se věnuji ukázkám výsledků vybraných zástupců segmentačních technik. Jedná se o segmentaci prahováním, která patří do kategorie segmentace založené na parametrickém vyjádření, dále uvádím ukázky výsledků po segmentaci na základě hranové reprezentace využitím různých hranových detektorů. Následujícím typem je regionově orientovaná segmentace zahrnující segmentaci růstem oblastí a segmentaci dělením a slučováním oblastí. Ze skupiny segmentace pomocí aktivních kontur jsem si vybral segmentaci pomocí ASM.

6.1 Segmentace prahováním

Segmentace prahováním představuje nejjednodušší metodu segmentace. Vstupem pro funkci je vstupní obraz a práh. Ve funkci se pak každý bod vstupního obrazu porovná se zadaným prahem a pokud je hodnota bodu (intenzita jasu) vyšší než zadaný práh, je výsledný bod nastaven na hodnotu 255. Pokud je hodnota bodu nižší, je výsledný bod vynulován a vzniká tak binární obraz (obr. 6.1). Existují i modifikace prostého prahování, jako je například dvojité prahování (obr. 6.2) a poloprahování (obr. 6.3). U dvojitého prahování jsou nastavovány hodnoty pixelů ležící mezi dvěma prahy, ostatní jsou nulovány. U poloprahování existuje podobně jako u prostého prahování pouze jeden práh. Hodnoty vyšší než tento práh nejsou nastavovány na hodnotu 255, ale jsou ponechány beze změn a hodnoty nižší jsou vynulovány.



Obr. 6.1: Originální obraz (vlevo) obraz po segmentaci prostým prahováním (vpravo) s parametrem $tresh=100$




Obr. 6.2: Originální obraz (vlevo) obraz po segmentaci dvojitým prahováním (vpravo) s parametrem `tresh1=80` a `tresh2=100`




Obr. 6.3: Originální obraz (vlevo) obraz po segmentaci polo prahováním (vpravo) s parametrem `tresh=80`

6.2 Segmentace na základě hranové reprezentace


Tato metoda segmentace představuje jednu z nejdůležitějších oblastí nižší úrovně zpracování obrazu. U detekce pomocí hranových detektorů rozlišujeme dva hlavní způsoby detekce hran. Jedná se o detekci hran pomocí první a druhé derivace. Nejvýznamnější hranové detektory využívající detekci hran pomocí první derivace jsou: Sobelův, Prewittův, Robertův a Cannyho hranový detektor, které vracejí hrany v těch místech, kde je gradient obrazu největší (obr. 6.4, obr. 6.5 a obr. 6.6). U detekce pomocí druhé derivace je nejznámější Laplacian (obr. 6.6), který využívá k detekci hran průchod nulovou hladinou. V tomto případě využívám k segmentaci přímo vestavěné funkce programu Matlab a segmentované obrazy pouze převádím na negativy, to pro lepší rozpoznatelnost.



Obr. 6.4: Originální obraz (vlevo) a výsledný obraz po použití Sobelova hranového detektoru (vpravo)




Obr. 6.5: Výsledný obraz po použití Prewittova (vlevo) a Robertsova hranového operátoru (vpravo)



Obr. 6.6: Výsledný obraz po použití Cannyho (vlevo) a Laplacian-Gaussian hranového operátoru (vpravo)

6.3 Segmentace růstem oblastí

Nejjednodušší metodou regionově orientované segmentace je segmentace růstem oblastí. Vstupem pro funkci „growing“ je obraz určený k segmentaci a dále také parametr *distance*, který udává maximální hodnotu odchylky jasu pro připojení zkoumaného pixelu do oblasti. Po zavolání funkce se objeví okno se vstupním obrazem pro výběr bodu, kde dvouklikem vybereme souřadnice, které nám udávají počáteční hodnotu průměru regionu. V případě, že velikost nejmenšího rozdílu intenzity pixelu od průměrné hodnoty intenzity celého regionu nepřevyšuje maximální zadanou hodnotu a pokud je velikost regionu menší než obraz, následuje v cyklu výpočet sousedních bodů od bodu naposledy přidaného do regionu. Z vypočítaných bodů se vybere jeden bod s intenzitou nejbližší k průměrné hodnotě intenzity regionu, který bude v příštím průběhu cyklem testován. Následuje testování pro přidání minule vybraného bodu do regionu, výpočet nového průměru regionu a uložení nových souřadnic bodu pro výpočet následujících sousedů. Výsledkem této funkce je binární obraz, kde jsou všechny body, které vyhověly podmínce zobrazeny bílou barvou, ostatní body zůstávají černé. Výsledky segmentace jsou ukázány na následujících obrázcích (obr. 6.7, obr. 6.8). Vidíme zde různé výsledky díky rozdílnému nastavení hodnoty *distance*. Právě tato hodnota udává, které části obrazu budou přidány do regionu. Pro lepší názornost jsou obrazy po segmentaci převedeny na negativy.



Obr. 6.7: Originální obraz (vlevo) a obraz po průchodu segmentací růstem oblastí s parametrem $distance=0,05$ (vpravo)




Obr. 6.8: Obrazy po průchodu segmentací růstem oblastí s parametrem $distance=0,09$ (vlevo) a s parametrem $distance=0,13$ (vpravo)


6.4 Segmentace dělením a slučováním oblastí:

Jedná se také o metodu regionově orientované segmentace. Vstupem pro funkci „splitmerge“ je obraz určený k segmentaci, práh (`threshold`), který udává, má-li být blok dále dělen, hodnota `mindim`, která udává minimální možnou velikost bloku při dekompozici a `stdtresh`, podle něhož se určují bloky, které mají být nastaveny na hodnotu 1. Vstupní obraz musí být před provedením dekompozice upraven na správnou velikost, to provedeme doplněním obrazu nulami. Následně provádíme dekompozici čtyřstromem, pokud jsou splněny podmínky. První podmínka je dána prahem a druhá velikostí nejmenšího bloku.

Poté se vytváří výsledný obraz tak, že jsou z obrazu vybírány bloky, které jsou znovu testovány. Pokud je standardní odchylka větší než hodnota nastavená v proměnné `stdtresh` je celý blok nastaven na hodnotu 1, pokud ne, zůstává mu hodnota 0. V následujících obrázcích (obr. 6.9, obr. 6.10) vidíme vliv parametru `mindim` na výsledný obraz, který je po segmentaci opět převeden pro lepší názornost na negativy.




Obr. 6.9: Originál (vlevo) a obraz po segmentaci dělením a slučováním oblastí (vpravo)
 `threshold=0,1, mindim=2` a parametr `sdtresh=10`



Obr. 6.10: Obrazy po segmentaci dělením a slučováním oblastí $\text{threshold}=0,1$, $\text{mindim}=4$, $\text{sdtresh}=10$ (vpravo) a $\text{threshold}=0,1$, $\text{mindim}=8$, $\text{sdtresh}=10$ (vlevo)

6.5 Aktive shape models:


Aktivní tvarový model vychází z toho, že by model mělo být možno deformovat pouze tak, aby odpovídal vzorovým tvarům z trénovací množiny. První je tedy nutné ručně vytvořit trénovací množiny bodů. V každém trénovacím obraze označíme hledaný tvar pomocí zvoleného počtu bodů a souřadnice těchto bodů uložíme do textového dokumentu. Tato skutečnost může být nevýhodou, zvláště když máme velké množství trénovacích obrazů. Funkce ASM využívá čtyři pomocné funkce. Jako první je nutné zavolat funkci `LoadModels`, která má na vstupu pouze počet trénovacích obrazů. V této funkci se jako první nastaví počet trénovacích bodů a v proměnné `ProfilLength` délka vytvářeného profilu. Poté jsou načteny trénovací obrazy a do proměnné `Models` jsou načteny i označené body, které jsou uloženy v textovém dokumentu. Dále vytváříme pomocí funkce `kolmice` v každém trénovacím bodě profil, který popisuje parametry obrazu v okolí každého označeného bodu. Vstupem pro funkci `kolmice` je dvojice bodů (`input`), abychom byli schopni vytvořit spojnici, proměnná `distance`, která udává vzdálenost od zadaného bodu, proměnná `Len` udávající délku profilu a proměnná `Angle` udávající úhel, který svírá vytvářený profil se spojnicí bodů. Tento profil je kolmý na spojnici dvou sousedních bodů a dlouhý dvojnásobek nastavené délky (profil vytváříme jak vpravo od spojnice tak i vlevo). V dalším kroku nahradíme každý prvek gradientem intenzity. To provedeme tak, že nahradíme profilový prvek v každé pozici i rozdílem mezi prvkem i a $i-1$ prvkem. Nakonec podělíme každý prvek výsledného vektoru sumou absolutních velikostí všech prvků vektoru a vypočítáme průměrný profilový model, který uložíme do proměnné `Profiles`.




Obr. 6.11: Ukázka vytvořeného profilového modelu

Jako poslední krok ve funkci `LoadModels` vytvoříme kovarianční matici `CovMat`, která je spolu s proměnnou `Models`, `Profiles` a `Proflength` také výstupem funkce.


Dále využíváme funkci `Alignment`, která má na vstupu načtené modely v proměnné `Models` (obr. 6.12), které je nutné zarovnat (obr. 6.13) a změnit jejich velikost, na výstupu pak dostáváme uspořádané tvary z trénovací množiny v proměnné `Align_models` (obr. 6.14).



Obr. 6.12: Tvary načtené z trénovací množiny



Obr. 6.13: Tvary z trénovací množiny po zarovnání na střed




Obr. 6.14: Tvary z trénovací množiny po zarovnání na střed a změně velikosti v proměnné `Align_models` (modře) a jejich průměrný tvar (červeně)

Následuje funkce PCA (analýza hlavních komponent), která má na vstupu modely seřazené ve funkci `Alignent`. Tato funkce nám vrátí průměrný tvar v proměnné `Mean_Shape`, matici vlastních vektorů `EigenVectors` a matici vlastních čísel `EigenValues`. Průměrný model se vypočítá jako prostý průměr všech seřazených tvarů z trénovací množiny. Matici vlastních vektorů a matici vlastních čísel vypočítáme rozkladem kovariační matice.


Po získání všech potřebných dat voláme funkci `ASM`. Tato funkce má na vstupu proměnnou `Mean_Shape`, `EigenVectors`, `EigenValues`, dále pak v proměnné `Input` obraz, ve kterém budeme hledat tvar určený trénovací množinou, potom proměnnou `Profiles`, `CovMat`, `ProfLength` a také proměnnou `Centre`, která nám udává pozici prvního bodu průměrného tvaru pro první hrubé přiblížení. V samotném algoritmu se musí jako první nastavit velikost počátečního tvaru `Mean_Shape` a počet bodů, které se budou prohledávat v okolí bodů určených v proměnné `Mean_Shape`, tato proměnná má název `SearchPoints`. Následně jsou vypočítány souřadnice bodů vstupního tvaru v obraze pomocí proměnných `Mean_Shape` a `Centre`. Nakonec se vstupní obraz zobrazí a vepíše se do něj průměrný tvar.

Poté začíná cyklus, ve kterém se provádí samotné tvarování průměrného tvaru modelu k hledanému tvaru v obraze. Tento cyklus je rozdělen na dvě části. V první části probíhá hledání nového tvaru pomocí profilových shod. Nejdříve je nutné vytvořit kolem každého bodu proměnné `Shape_Rec` profily pomocí funkce `kolmice`. Vzdálenost těchto profilů od bodů určuje proměnná `SearchPoints`. Profily se vytvářejí na obě strany od bodu ve vzdálenosti `-SearchPoints` do `SearchPoints`. U takto vytvořených profilů nahradíme každý prvek gradientem intenzity a podělíme každý prvek výsledného vektoru sumou absolutních velikostí všech prvků vektoru. Následuje výpočet Mahalanobisovy vzdálenosti. Ta určuje který z prozkoumávaných vektorů se nejlépe shoduje s profilem vytvořeným na trénovacích obrazech. Střed profilu, který má tuto vzdálenost nejmenší, je místem pro novou navrhovanou pozici bodu. Následně je obraz i s novým navrhovaným modelem vykreslen (obr. 6.15).



Obr. 6.15: Výřez vstupního obrazu se zobrazeným vstupním tvarem (vlevo) a tvar po prvním průchodu profilovým modelem (vpravo)


Ve druhé části tohoto cyklu se upravuje tvar navržený profilovým modelem pomocí tvarového modelu, který definuje škálu povolených tvarů (obr. 6.16). Tento krok je velmi důležitý, protože profilové schody jsou nevěrohodné a z určité části může jít pouze o náhodné schody. Výsledek po průchodu tvarovým modelem je také vykreslen.



Obr. 6.16: Výřez vstupního obrazu se zobrazeným tvarem po prvním průchodu profilovým modelem (vlevo) a po následné úpravě tvarovým modelem (vpravo)


Následuje podmínka hlavního cyklu. Ten se ukončí pouze v případě, že již téměř nedochází ke změně modelu, nebo v případě, že bylo dosaženo maximálního počtu iterací. Po skončení dojde k vykreslení vstupního obrazu s přizpůsobeným tvarem.

Pro určení hledaného tvaru je velmi důležité správně zadat počáteční velikost tvaru a souřadnice prvního bodu. Z obrázku 6.17 je vidět průběh tvarování modelu při správně zadaných hodnotách. Vidíme postupné přibližování modelu ke hranici objektu obrazy.




Obr. 6.17: Výřez vstupního obrazu se zobrazeným vstupním tvarem a), tvarem po třetí b), třinácté c) a tvarem po třicáté první iteraci d)


Obrázek 6.18 znázorňuje průběh deformace modelu při chybně zadaných souřadnicích prvního bodu modelu. Z výsledků je zřejmé, že aktivní tvarový model není schopen nalézt pravý hledaný objekt. Díky tomu, že je vložený průměrný tvar vychýlen a částí zasahuje mimo hledaný objekt, dochází po průchodu profilovým modelem k výběru nesprávných bodů, které představují novou pozici.



a)



b)



c)



d)

Obr. 6.18: Výřez vstupního obrazu se zobrazeným vstupním tvarem a), tvarem po třinácté b), třicáté c) a tvarem po padesáté první iteraci d)

7 Závěr

V rámci této diplomové práce jsem se podrobněji seznámil se způsoby segmentace obrazových dat. Jednalo se o segmentaci založené na parametrickém vyjádření, kde jsem si jako parametr vybral jas. Tato metoda je nejstarším způsobem segmentace. V jednoduchých případech je stále používána a vzhledem ke své výpočetní nenáročnosti je jednou z nejrychlejších metod. Je to nejjednodušší metoda, ve které určujeme práh, podle něhož rozhodujeme o hodnotě pixelu. Problém však může nastat při určování prahu. Zpravidla není možné úspěšně použít jediný práh na celé ploše obrazu, dokonce ani ve zcela jednoduchých scénách nemusí dát globální prahování s jediným prahem požadované segmentační výsledky.

V další části se věnuji segmentaci na základě hranové reprezentace. Tato metoda představuje jednu z nejdůležitějších oblastí nižší úrovně zpracování obrazu. Hranové detektory můžeme rozdělit na detektory využívající první a druhou derivaci. U detekce hran pomocí první derivace musíme výsledek porovnat s prahem, který určuje, zda se jedná o hranu. U detekce pomocí druhé derivace se k určení hran výhradně používá detekce průchodu nulovou hladinou. Jednotlivé hranové detektory se liší jádrem konvolučního filtru, jehož velikost a vlastnosti výrazně ovlivňují výsledky detekce a obecně platí, že čím větší je konvoluční filtr tím je větší odolnost vůči šumu v obraze. Metody detekce hran pomocí druhé derivace jsou citlivější na šum, a proto je vhodné kombinovat tuto metodu s metodou odstraňující šum a přitom nepoškozující hrany v obraze.

V praxi se nesetkáváme pouze s ideálními obrazy, ale vyskytují se i obrazy s přítomností šumu popřípadě s obrazy, které obsahují neostře hrany. Pro tyto obrazy je efektivnější použít regionově orientovanou segmentaci, která je výpočetně náročnější, protože hranové detektory by mohly zkreslit výstupní obraz. Nejjednodušší varianta této metody je segmentace růstem oblastí, kde seskupujeme sousední pixely s podobnými vlastnostmi. Další způsob je segmentace dělením a slučováním oblastí, kdy celý obraz dělíme do jednotlivých oblastí tak dlouho, dokud není splněna podmínka stejnorodosti. Pokud oblasti podmínku splňují, dojde k jejich sloučení a dále se už nedělí.

V poslední kapitole se zabývám segmentací pomocí pružných a aktivních kontur. Jedná se o postupné tvarování kontur až ke hraně objektu v obraze. Metoda ASM vychází z toho, že model by mělo být možné deformovat pouze tak, aby odpovídal vzorovým tvarům z trénování množiny. U tohoto způsobu segmentace je důležité mít dostatečné množství vzorových tvarů což je u lékařských obrazů obsahujících citlivá data o pacientech nelehký úkol. Také je velmi důležité správně zadat vstupní informace o počáteční poloze hledaného tvaru v obraze a velikosti průměrného tvaru z trénovací množiny. Při špatném zadání těchto údajů může dojít k selhání celé metody.

Seznam použité literatury

- [1] CÍSAŘ, P. *Využití metod odezírání ze rtů pro podporu rozpoznávání řeči*. [s.l.], 2004. 45 s. Dizertační práce.
- [2] COOTES, T.F., TAYLOR, C.J.. *Statistical models of appearance for computer vision*. Active shape models [online]. 2004 [cit. 2009-03-09]. Dostupný z WWW: <http://www.face-rec.org/algorithms/AAM/app_models.pdf>.
- [3] HLAVÁČ, V, SEDLÁČEK, M. *Zpracování signálů a obrazů*. 2. přeprac. vyd. Praha : ČVUT, 2007. 255 s. ISBN 978-80-01-03110-0.
- [4] HLAVÁČ, V, ŠONKA, M. *Počítačové vidění*. [s.l.] : Grada Praha, 1992. 252 s. ISBN 80-85424-67-3
- [5] HUBENÝ, J. *3D Reconstruction of Interphase Chromosomes*. RNDr. Thesis [online]. 2005 [cit. 2008-12-09]. Dostupný z WWW: <http://is.muni.cz/th/4012/fi_r/r.pdf?lang=cs>.
- [6] JÁN, J. *Analýza signálů a obrazů*. Podpora k přednáškám předmětu MASO [online]. 2007 [cit. 2008-12-09]. Dostupný z WWW: <<http://www.dbme.feec.vutbr.cz/ubmi/courses/MASO/MASO08.pdf>>.
- [7] JÁN, J. *Analýza signálů a obrazů*. Podpora k přednáškám předmětu MASO [online]. 2007 [cit. 2008-12-09]. Dostupný z WWW: <<http://www.dbme.feec.vutbr.cz/ubmi/courses/MASO/MASO09.pdf>>.
- [8] JÁN, J. *Medical Image Processing, Reconstruction and Restoration - Concepts and Methods*. Boca Raton, FL, USA: CRC Press, Taylor and Francis Group, 2006. 730 s. ISBN 0-8247-5849-8.
- [9] KALOVÁ, I. *Úpravy obrazu*. Detekce a parametrizace geometrických tvarů – Houghova transformace [online]. 2007 [cit. 2008-12-09]. Dostupný z WWW: <<http://www.uamt.feec.vutbr.cz/vision/TEACHING/MPOV/07%20-%20Detekce%20a%20parametrizace%20geometrickych%20tvaru.pdf>>.

- [10] MAŠKA, M. *Segmentace obrazu pomocí rychlých aproximací implicitních aktivních povrchů*. [s.l.], 2006 [cit. 2008-12-09]. 53 s. Masarykova univerzita, Fakulta informatiky. Diplomová práce. Dostupný z WWW: <http://is.muni.cz/th/60734/fi_m/print.pdf>.
- [11] MICHALÍK, M. *Algoritmy pro rozpoznávání obličeje*. [s.l.], 2008. 76 s. Bakalářská práce. Dostupný z WWW: <https://www.stag.utb.cz/apps/stag/dipfile/index.php?download_this_unauthorized=9103>.
- [12] MILBORROW, S. *Locating facial features with active shape models*. [s.l.], 2007. 103 s. Dizertační práce.
- [13] ŠPANĚL, M, BERAN, V. *Obrazové segmentační techniky*. Přehled existujících metod [online]. 2005 [cit. 2008-12-09]. Dostupný z WWW: <<http://www.fit.vutbr.cz/~spanel/segmentace/.en>>.
- [14] *The MathWorks* [online]. c1994-2009 [cit. 2009-04-10]. Dostupný z WWW: <<http://www.mathworks.com/>>.
- [15] ŽELEZNÝ, M. *Zpracování digitalizovaného obrazu*. Matematická morfologie [online]. 2006 [cit. 2009-03-20]. Dostupný z WWW: <http://147.228.47.19/courses/zdo/ZDO_aktual_060217.pdf>.
- [16] XU, Ch; PRINCE, J. *Image analysis and communications lab : Aktive contours, Deformable models, and gradient vector flow* [online]. Johns Hopkins University : c2002-2008 [cit. 2008-12-09]. Dostupný z WWW: <<http://iacl.ece.jhu.edu/projects/gvf/>>.

Seznam použitých veličin a symbolů

B, X, Y	množiny bodů
$C(t)$	uzavřená křivka v prostoru
D	množina prahů
E_{constrai}	energie reprezentující externí síly
E_{edge}	energie tvarující kontury k hranám
E_{image}	vnější energie
E_{internal}	vnitřní energie křivky způsobená zakřivením
E_{line}	energie určující přitažlivost kontury k světlejším nebo tmavším částem obrazu
E_{term}	energie detekující ostré hrany a konce hran pomocí zkoumání křivosti
$f(i,j)$	vstupní obraz
g	vyhledávací profil
\bar{g}	průměrný profil
$g(i,j)$	výstupní obraz
$G(i,j)$	výsledný gradient obrazu
$G_R(i,j)$	gradient obrazu po detekci hran pomocí první derivace pro řádky
$G_S(i,j)$	gradient obrazu po detekci hran pomocí první derivace pro sloupce
$H(j,k)$	výsledná impulsní charakteristika filtrů
$H_R(j,k)$	impulsní charakteristika filtrů pro řádky
$H_S(j,k)$	impulsní charakteristika filtrů pro sloupce
k	křivost rozhraní
l_i, l_j	délky obvodů jednotlivých regionů
m_c	střední hodnota
\vec{N}	normálový vektor
s	délka křivky
$s_{i,j}$	síla hrany
S_s	kovarianční matice
T	práh
$v(s)$	parametrická křivka
$v_{i,j}$	segmentovaná oblast
V	diagonální matice
W	počet slabých hran společné hranice
$w_{\text{line}}, w_{\text{edge}}, w_{\text{term}}$	váhové faktory
\hat{x}	tvarový vektor
$\overline{x_0}$	průměrný tvar

$\tilde{\mathbf{x}}_l$	transformované vektory
x_{posun}	hodnota posunutí bodu ve směru x
y_{posun}	hodnota posunutí bodu ve směru y
$\alpha(t), \beta(t)$	váhové funkce definující hladkost a pružnost kontury
δ_c^2	variance z množiny trénovacích vektorů
ε	minimální chyba
θ	úhel
$\theta(i,j)$	orientace gradientu v obraze
ρ	normalizovaná vzdálenost přímky od počátku
$\sigma()$	směrodatná odchylka
$\sigma^2()$	rozptyl
Φ	matice vlastních vektorů
∇	označení gradientu
\oplus	morfologická operace označení dilatace
\ominus	morfologická operace eroze
\circ	morfologická operace otevření
\bullet	morfologická operace uzavření

Seznam použitých zkratk

ASM	aktivní tvarový model (Active Shape Models)
PCA	analýza hlavních komponent (Principal Component Analysis)

Seznam příloh

A	Obsah CD	58
---	----------------	----

A Obsah CD

Adresářová struktura na CD nenásledující:

- adresář *Active shape models* – obsahuje funkce, obrazy a textové soubory potřebné pro segmentaci obrazu pomocí metody ASM
- adresář *Segmentace dělením a slučováním oblastí* – obsahuje funkci a zkušební obraz pro segmentaci dělením a slučováním oblastí
- adresář *Segmentace na základě hranové reprezentace* – obsahuje skript a zkušební obraz pro segmentaci na základě hranové reprezentace
- adresář *Segmentace prahováním* – obsahuje funkce a zkušební obraz pro segmentaci pomocí prahování
- adresář *Segmentace růstem oblastí* – obsahuje funkci a zkušební obraz pro segmentaci růstem oblastí
- adresář *text* – obsahuje tuto práci ve formátu pdf

K vytvoření všech skriptů byl použit program MATLAB verze 7.6.0.324.